基于深度卷积神经网络的大学英语四级考试成绩早期预警

王宝[1]， 罗淼[2]

（1. 兰州交通大学 外国语学院，甘肃 兰州 730070；2.兰州交通大学 铁道技术学院，甘肃 兰州 730099 ）

[摘 要] 大学英语四级考试成绩早期预警模型易受学生日常行为模式差异干扰，影响预测精度。以某智慧教学平台上与大学英语四级考试直接相关的四级题型模块化学习成绩作为数据来源，建立模块化学习灰度图片数据库，同时将深度学习引入早期预警，形成基于深度卷积神经网络的大学英语四级成绩预警模型，对学生是否能在大学英语四级考试中取得预期成绩进行前期预测。验证结果表明，深度卷积神经网络预测模型相较于现有的预测模型具有更高的预测精度，可得到更早的最佳干预时间，有利于教师更好地对风险学生进行干预，提高学生大学英语四级考试成绩，提升英语语言应用能力。

[关键词] 全国大学英语四级考试；早期预警；深度卷积神经网络；预测精度；最佳干预时间

一. 引言

已实施三十余年的全国大学英语四、六级考试作为一项国家级英语水平测试，其信度、效度以及区分度得到了众多高校与社会各界的广泛认可，是衡量大学生英语应用水平的科学标准，对高校大学英语教学有重要导向作用。"大学英语四、六级考试是为大学英语课程体系服务的教育考试。四、六级考试设计的基本原则是根据大学英语课程要求确定测试目标，并运用应用语言学领域的研究成果界定考试构念"[1]。如能在举行四六级考试前通过分析学生学习大学英语课程的相关情况，预测考试结果，并根据预测结果进行学生学业早期预警、确定触发教学干预的时间，给出教学决策，则十分有利于提高教师大学英语教学水平，提高学生的大学英语四级考试成绩与英语实际应用能力。目前，在学习分析方面，学者对学业早期预警、教学决策以及教学干预方面已有较多研究。

目前，已有研究采用本科生评估数据以及个人信息数据建立了早期预警模型，重点研究最佳干预时间。通过分析验证，得出最佳干预时间为课程中期，且需要学生自身改变学习策略以适应新的课程学习要求。[2]另有研究以学生阅读电子书的数据为基础建立了机器学习预测模型，同时得出采取教学干预的最佳时间。为验证所建立模型的优越性，文中与多种算法模型加以对比，证实了该模型的预测结果精度最高。[3]此外，王华、刘萍以改进的 Apriori 算法分析并预测学生成绩数据，通过课程之间的关联规则给出学生成绩预警，及时标注存在不及格风险的课程，加强学习监督，提高课程通过率。[4]以上研究主要用于预测累计行为频率，所建立的预测模型易受不同学习行为模式之间的差异，课程活动随课程进展而变化等因素的影响，预测准确度较低。

部分学者也将神经网络算法应用于学业预警中。宋楚平、李少芹等提出一种基于 RBF 神经网络的学习预警算法，建立了适用于学业预测的 RBF 神经网络模型，通过遗传算法对传统 RBF 网络权重向量进行全局搜索以得到最优模型，提升了模型的收敛速度及预测精度。[5]但是，该模型的影响因子由专家和任课教师依赖个人经验评定，可靠性较低。翁泉源以 BP 神经网络为基础，通过挖掘各学科成绩之间的关系以及学期历史成绩的发展趋势来预测学生最终的结业成绩。[6]另有学者使用人工神经网络，以学习绩点作为输入与输出方法，预测工程学专业学生的学业成绩。[7]郎波、樊一娜以在线学习过程中产生的数据为基础，建立了 GA-BP 在线成绩预测模型，通过与真实成绩分布情况对比，验证了模型的预测精度，证明其所用方法的可信度及有效性。[8]刘爱萍以学生日常行为数据为基础，采用 KNN 算法提取数据特征，得到所需预测因子，提高了模型的预测准确性，解决了传统成绩预测模型所得结果置信度过小的问题。[9]姜绍萍针对教育大数据背景下高校学生管理面临的问题，提出一种 GA-BP 学生学业预警算法。其研究选取了 8 个相关系数较高的行为特征数据作为网络输入，可将最终的预警准确率提高到 90%以上。[10]以上多数研究均以 BP 神经网络为基础建立预测模型，着重关注预警结果正确性，而 BP 神经网络的训练速度较慢、有极易陷入局部最优等缺点，得到的教学干预时间较晚，导致教师对风险学生的教学干预时长不足，影响最终干预效果。

目前，深度学习已在图像和语音处理等方面得以广泛应用，并逐渐成为多领域研究热点。因此，有学者将深度卷积神经网络引入学业预警模型中，但相关研究较少。例如，有的学者在虚拟学习环境中，对深度人工神经网络进行前期数据挖掘，并将之成功应用于学业预警中。[11]张明焱等结合学生微观行为模式，采用

LSTM-Autoencoder 对学生行为时间序列作特征处理，以深度学习模型进行学习成绩早期预测，提高了预测的准确度，并在一定程度上提前了教学干预开始时间。[12]

从目前的研究内容和研究方法来看，大部分研究都以学生学习行为为基础，从而预测学业成绩。然而，学生的部分行为模式与学业成绩相关性较低，日常学习行为统计工作量巨大，这些因素降低了预测结果的准确度，得出的教学干预时间往往过晚。另外，专门着力于大学英语四、六级成绩的预测研究几为空白。本文为解决以上问题，以参与人数更多的大学英语四级考试为例，结合学生进行大学英语四级模块化专项训练的相关数据结果，提出一种基于深度卷积神经网络的大学英语四级成绩早期预测模型。该模型利用深度学习在图片识别中的优势，将学生的模块化训练数据转化为灰度图片，再将其输入到模型中进行训练，并以经过充分训练的预测模型对大学英语四级成绩做出预测。通过对比分析验证，证明本文所建立的深度卷积神经网络大学英语四级成绩早期预测模型准确度更高，并且能够获取更早的教学干预时间。

二．数据来源及数据预处理

（一）数据来源

本文数据采集自某智慧教学平台。该平台提供教、学、评、测、研一站式解决方案，可进行与大学英语四级考试相对应的阅读、写作、听力、翻译等专项模块化学习与训练。平台使用者可从后台获取大量专项模块化学习与训练数据。图 1 所示为系统储信息记录，图中仅截取展示部分信息。



序号	教程	课程	班级	完成人数	操作
1	新六级写作通关特训	大学英语综合3			班级详情 学生详情
2	新六级翻译通关特训	大学英语综合3			班级详情 学生详情
3	新四级强化辅导 写作	大学英语综合3			班级详情 学生详情
4	新四级强化辅导 翻译	大学英语综合3			班级详情 学生详情
5	新视野大学英语（第三版）综合训练3	大学英语综合3			班级详情 学生详情
6	新视野大学英语（第三版）读写思政数字课程3	大学英语综合3			班级详情 学生详情
7	突破职场英语写作	大学英语综合3			班级详情 学生详情
8	考研英语备考详解	大学英语综合3			班级详情 学生详情
9	新六级写作通关特训	大学英语综合3			班级详情 学生详情
10	新六级翻译通关特训	大学英语综合3			班级详情 学生详情
11	新四级强化辅导 写作	大学英语综合3			班级详情 学生详情
12	新四级强化辅导 翻译	大学英语综合3			班级详情 学生详情
13	新视野大学英语（第三版）综合训练3	大学英语综合3			班级详情 学生详情

图 1 系统后台存储信息记录

（二）数据预处理

从平台获取的数据默认按照时间次序排列，包含大量冗余信息。例如，在该平台查看学生某一周阅读模块练习情况，获取的信息不仅包含该模块练习所获得的分数，还包括目标 IP、目标端口、登录时间、专业名称、班级等冗余信息，因此，必须对原始数据进行预处理。本文以 Kendall 相关性分析提取有用数据。

Kendall 相关性分析适用于连续数据分析，如学习时长与大学英语四级考试成绩之间是否具有相关性的分析即适用此方法。首先，按等级大小对一组数据进行排序。本文将四级考试考试成绩达到预期记为 1，未达到记为 0。该组数据仅分为两个等级，可大幅度缩短用于排序和比较的计算时长。Kendall 相关性系数可用于衡量两个随机变量之间的相关性参数，取值范围在-1~1 之间；系数值越大，两个变量的负相关关系越强。[13]本文采用 Kendall 相关性分析的主要目的在于发掘每一种数据与学生四级考试成绩是否达到预期的相关关系，因此不需考虑正负相关的影响，直接取 Kendall 相关系数的绝对值$|K|$作为本文的相关系数，计算公式如式(1)所示。

$$|K| = \left|\frac{C - D}{\sqrt{(N_3 - N_1)(N_3 - N_2)}}\right| \tag{1}$$

其中，C 为两组数据中具有一致性的数据对的对象；D 为两组数据中不具有一致性的数据对的对数。例如，(X_i, Y_i) 和 (X_j, Y_j) 为一对数据对，若 $X_i<X_j$ 且 $Y_i<Y_j$，即表明该数据对具有一致性；若 $X_i<X_j$ 且 $Y_i>Y_j$，即表明该数据对不具有一致性。式中的 N_1、N_2 及 N_3 的计算方法如式(2)：

$$\begin{cases} N_1 = \sum_{i=1}^{S} \frac{1}{2} U_i(U_i - 1) \\ N_2 = \sum_{i=1}^{T} \frac{1}{2} V_i(V_i - 1) \\ N_3 = \frac{1}{2} N(N - 1) \end{cases} \tag{2}$$

其中，S 为第 1 组数据中拥有相同元素的小集合的个数，U_i 为第一组数据中每个小集合中元素的个数，T 为第 2 组数据中拥有相同元素的小集合的个数，V_i 为第 2 组数据中每个小集合元素的个数，N 为样本总数。

选取 2019 年至 2021 年间四级专项模块化练习相关数据信息，结合 Kendall 相关系数计算方法，得到该平台上四级专项模块训练相关数据与四级考试成绩是否达标之间的相关系数，成绩、完成度、练习次数三项指标与学生四级考试是否达到预期的相关性最高，相关性系数均在 0.5 以上。其中，成绩这一项的相关性系数最高。成绩信息指大学英语四级考试题型专项模块化练习成绩，因此，主要考虑以平台成绩信息开展大学英语四级考试成绩早期预警研究。

三．基于深度卷积神经网络的英语四级成绩早期预警算法

（一）创建学生模块化学习灰度图片数据库

为了将深度学习应用于四级成绩的早期预警，首先要将平台数据信息转化为灰度图片，建立学生模块化学习灰度图片数据库。成绩信息对于学生四级考试是否达到预期的权重值最大，因此，从平台中导出写作、听力、阅读及翻译四个模块的专项训练得分，则某个学生在平台进行一次完整的四级题型专项训练后获得的成绩可表示为式(3)：

$$s_j = (s_i^{\mathrm{w}},\ s_i^{\mathrm{l}},\ s_i^{\mathrm{r}},\ s_i^{\mathrm{t}}) \tag{3}$$

其中，s_j 表示学生 j 在第 i 次四级题型专项训练中所获得的各模块的成绩；$\mathrm{s_i^w}$表示第 i 次写作模块训练的成绩；$\mathrm{s_i^l}$表示第 i 次听力模块训练的成绩；$\mathrm{s_i^r}$表示第 i 次阅读模块训练的成绩；$\mathrm{s_i^t}$表示第 i 次翻译模块训练的成绩；

本文采集某学生在一个学期(按最长 20 周设置)中每一天进行模块化专项训练所获得的的成绩，则该生在本学期所获得的成绩可记为如下二维矩阵：

$$S_j = \begin{bmatrix} s_1^{\mathrm{w}} & s_1^{\mathrm{l}} & s_1^{\mathrm{r}} & s_1^{\mathrm{t}} \\ \vdots & \vdots & \vdots & \vdots \\ s_i^{\mathrm{w}} & s_i^{\mathrm{l}} & s_i^{\mathrm{r}} & s_i^{\mathrm{t}} \\ \vdots & \vdots & \vdots & \vdots \\ s_N^{\mathrm{w}} & s_N^{\mathrm{l}} & s_N^{\mathrm{r}} & s_N^{\mathrm{t}} \end{bmatrix} \tag{4}$$

为把原始四级题型模块化训练成绩二维矩阵转化为模块化学习灰度图片，需要对上述 S_j 矩阵做形式与内容变换。首先，将 S_j 矩阵的每一列变换为 $\sqrt{N} \times \sqrt{N}$ 的矩阵。变换后形成 4 个子矩阵，分别为 $A_{j,1}$、$B_{j,2}$、$C_{j,3}$，$D_{j,4}$，新的矩阵 S_j 转换成大小为 $2\sqrt{N} \times 2\sqrt{N}$ 的矩阵，其形式如式（5）所示：

$$S_j = \begin{bmatrix} A_{j,1} & B_{j,2} \\ C_{j,3} & D_{j,4} \end{bmatrix}, j = 1,2,\cdots,U \tag{5}$$

其中，子矩阵 $A_{j,1}$、$B_{j,2}$、$C_{j,3}$，$D_{j,4}$ 分别表示为以下形式：

$$A_{j,1}=\begin{bmatrix} s_1^{\mathrm{w}} & s_2^{\mathrm{w}} & \cdots & s_{\sqrt{N}}^{\mathrm{w}} \\ s_{\sqrt{N}+1}^{\mathrm{w}} & s_{\sqrt{N}+2}^{\mathrm{w}} & \cdots & s_{2\sqrt{N}}^{\mathrm{w}} \\ \vdots & \vdots & \cdots & \vdots \\ s_{N-\sqrt{N}+1}^{\mathrm{w}} & s_{N-\sqrt{N}+2}^{\mathrm{w}} & \cdots & s_N^{\mathrm{w}} \end{bmatrix}$$

$$B_{j,1}=\begin{bmatrix} s_1^{1} & s_2^{1} & \cdots & s_{\sqrt{N}}^{1} \\ s_{\sqrt{N}+1}^{1} & s_{\sqrt{N}+2}^{1} & \cdots & s_{2\sqrt{N}}^{1} \\ \vdots & \vdots & \cdots & \vdots \\ s_{N-\sqrt{N}+1}^{1} & s_{N-\sqrt{N}+2}^{1} & \cdots & s_N^{1} \end{bmatrix}$$

$$C_{j,1}=\begin{bmatrix} s_1^{\mathrm{r}} & s_2^{\mathrm{r}} & \cdots & s_{\sqrt{N}}^{\mathrm{r}} \\ s_{\sqrt{N}+1}^{\mathrm{r}} & s_{\sqrt{N}+2}^{\mathrm{r}} & \cdots & s_{2\sqrt{N}}^{\mathrm{r}} \\ \vdots & \vdots & \cdots & \vdots \\ s_{N-\sqrt{N}+1}^{\mathrm{r}} & s_{N-\sqrt{N}+2}^{\mathrm{r}} & \cdots & s_N^{\mathrm{r}} \end{bmatrix}$$

$$D_{j,1}=\begin{bmatrix} s_1^{\mathrm{t}} & s_2^{\mathrm{t}} & \cdots & s_{\sqrt{N}}^{\mathrm{t}} \\ s_{\sqrt{N}+1}^{\mathrm{t}} & s_{\sqrt{N}+2}^{\mathrm{t}} & \cdots & s_{2\sqrt{N}}^{\mathrm{t}} \\ \vdots & \vdots & \cdots & \vdots \\ s_{N-\sqrt{N}+1}^{\mathrm{t}} & s_{N-\sqrt{N}+2}^{\mathrm{t}} & \cdots & s_N^{\mathrm{t}} \end{bmatrix}$$

按 20 个教学周，每周 5 个工作日采集该生四级考试题型模块化专项训练分数，计算该生在一个学期内获取成绩的次数。取其中前 64 次和前 100 次的数据，经以上变换，可将该生任一学期四级题型专项训练成绩表示为一张 16×16、20×20 灰度图片，如图 2 所示。

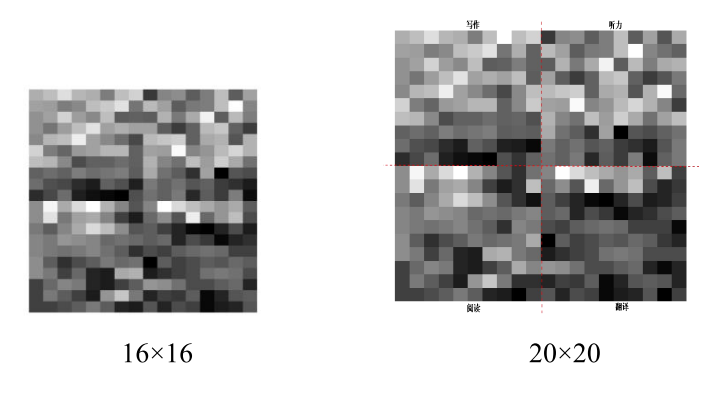


图 2 16×16 与 20×20 模块化学习灰度图片

图 2 共分为四个模块。左上部分为写作模块成绩对应灰度值；右上部分为听力模块成绩对应灰度值；左下部分为学生阅读模块成绩对应灰度值；右下部分为学生翻译模块成绩对应灰度值。

（二）基于深度卷积神经网络的英语四级成绩早期预警模型

卷积神经网络主要由输入层、卷积层、激活函数、池化层、全连接层、损失函数组成，其本质为特征提取和决策推断。组合以上网络结构，根据不同问题修改其参数，以提高特征提取和决策推断的正确率。

通过多个卷积层和池化层在卷积神经网络模型中对灰度图像的灰度值矩阵 $\boldsymbol{T}$ 进行处理，以达到降维、升维或者特征值提取的目的。卷积神经网络模型中第 i 层的输出可以用 $\boldsymbol{H}t$ 表示，这里 Ht_0=$\boldsymbol{T}$，如第 i 层为卷积层，那么，$\boldsymbol{H}t_i$ 可以描述为：

$$\boldsymbol{H}t_i = f(W_i * \boldsymbol{H}t_i + b_i) \quad (6)$$

其中，W_i表示第 i 层卷积核的权重值；*表示卷积运算；W_i与卷积网络中第 i-1 层的特征矩阵 Ht_i-1 层的特征矩阵 Ht_i-1 进行卷积，b_i为当前偏移量，$f()$为一线性函数的激励。

池化具有放大重要信息，淡化不重要的信息的功能，并能在保证特征尺度不变的前提下减少矩阵维数。常用的池化方法有最大值池化和平均值池化两种。对卷积后的特征矩阵进行池化可以得到池化后的特征矩阵 $\boldsymbol{Ht_i}$，如式（7）所示：

$$\mathbf{H}t_i = pooling(\mathbf{H}t_{i-1}) \tag{7}$$

灰度图片经卷积层、池化层后，再经过全连接层分类，完成输入到输出的映射，得到预测结果。

采用 3.1 节所述方法变换四级题型模块化训练成绩的二维矩阵数据集，得到模块化学习灰度图片数据集，并将其分为训练样本集（含验证样本集）和测试样本集。数据样本集包含代表位置指纹采样点的二维灰度图片，其与手写体数据集具有较高的相似性。以手写体数据集分类中具有极高准确率的 LetNet-5 为基础，结合本文所建立的模块化学习灰度图片特征，建立适用于大学英语四级考试成绩预警的卷积神经网络预测模型，其具体结构如图 3 所示。模型输入为 20×20×1 规格的灰度图片；模型中第一个卷积层的卷积核尺寸为 5×5，深度取 32，步长为 1，使用全零填充，输出为 20×20×32 的节点矩阵；第一个池化层中过滤器大小为 2×2，步长为 1；第二个卷积层中卷积核尺寸为 5×5，深度为 64，步长为 1，使用全零填充，输出为 10×10×64 的节点矩阵；第二个池化层的过滤器大小为 2×2，步长为 1，输出为 5×5×16 的矩阵；两个全连接层分别包含 1656 个与 175 个神经元。经全连接层输出后，通过 softmax 输出最终预测结果。

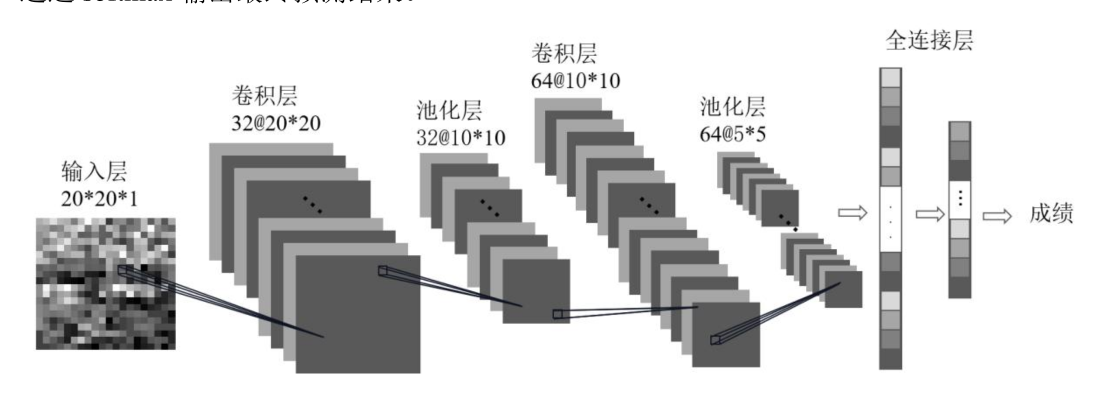


图 3 基于深度卷积神经网络的大学英语四级考试成绩预测模型

以 20×20 的图像为例分析该模型的计算过程：在 C1 卷积层中输入灰度指纹图片；首先使用 6 个 5×5 的卷积核，2×2 的最大池化，步长为 1，对图像进行操作，形成 6 个 10×10 的特征图；然后，再使用 16 个 5×5 的卷积核，2×2 的最大池化，步长为 1，对图像进行操作，形成 16 个 5×5 的特征图；之后，变换数据格式，生成用于分类的 1×5×5×16 的数据。因本文的灰度指纹图像较小，因此设计时减小了网络结构卷积核和池化的尺寸，以提高特征提取能力。相对于 LeNet-5 来说，本文减少了一个全连接层，以降低网络复杂度。为防止过拟合，并维持训练模型相对简洁，在全连接层后添加 Dropout 层，取值为 0.5。

四．实验验证及结果分析

（一）模型参数选择

为验证该模型的有效性，本文以平台数据进行实验。以 2019 年至 2021 年间某个学期（共 20 周的数据）大学英语四级专项模块化训练成绩数据为基础，按前文所述方法形成模块化学习灰度图片 15721 张，其中训练集灰度图片 12577 张（含验证集灰度图片 2515 张），测试集灰度图片 3144 张。本文根据以往实验设定模型参数，并在本次实验中不断调整至最优值。本文构建的预测模型相关参数如表 2 所示。其中，训练模型的初始学习率为 0.05，使用了指数衰减法；为了用较大的学习率获得较优的解，设置学习率衰减系数为 0.96，学习率随迭代次数不断减小，维持了后期模型训练的稳定性；滑动平均模型衰减率为 0.9999，该值越大，模型越趋于稳定。为提升模型在训练前期的更新速度，以 num-updates 参数动态设置滑动平均衰减率的大小，如式(8)所示。

$$\min\{\text{decay}, \frac{1+\text{num_updates}}{10+\text{num_updates}}\} \tag{8}$$

本文使用交叉熵函数作为模型训练的损失函数，[14]如式(9)所示。

$$H(p,q) = -\sum_x p(x)\log q(x) \tag{9}$$

其中，p 为给定的正确值概率分布，q 为给定的预测值概率分布。

同时以 L2 正则化和 dropout 处理过拟合。L2 正则化的计算公式为[15]：

$$R(w) = \|w\|_2^2 = \sum_i |w_i^2| \tag{10}$$

其中，w 为确定模型复杂度的权重值。

表 1　实验参数表

参数名称	参数值	参数说明
单样本采集天数	100	单个学生采集的天数
Learning-Rate	0.05	训练模型初始学习率
Decay-Rate	0.96	学习率衰减系数
Exponential Moving Average	0.9999	滑动平均模型衰减率
Regularizer L2	0.0001	L2 正则化权重
dropout	0.5	卷积网络全连接层

ReLU 以及 Elu 两种激活函数为常用激活函数。两种激活函数如式(11)和式(12)所示[16]：

ReLU 激活函数：

$$y = \begin{cases} 0 & (x \le 0) \\ x & (x > 0) \end{cases} \tag{11}$$

Elu 激活函数：

$$y = \begin{cases} \gamma(e^x - 1) & (x \le 0) \\ x & (x > 0) \end{cases} \tag{12}$$

ReLU 激活函数为分段线性函数，属单抑制函数，能使神经元具有稀疏激活性。Elu 激活函数存在负值，可将激活单元的输出均值向 0 推近，具有批量归一化效果，而且减少了计算量。图 4 所示为两种激活函数的网络损失收敛图。从结果可知，达到最佳收敛值时，ReLU 的训练轮次比 Elu 的训练轮次少 180 轮左右。因此，本文选用 ReLU 作为网络训练过程中的激活函数。

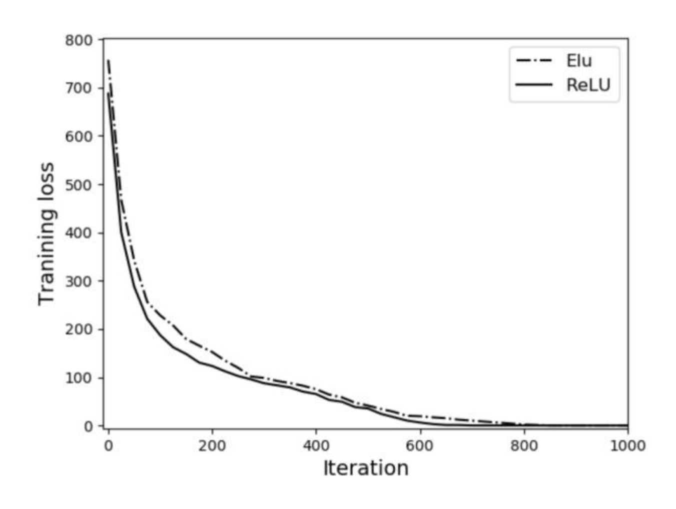


图 4 不同激活函数的网络损失收敛图

（二）确定模块化学习灰度图片规格

按第 3 章第 1 节中模块化学习灰度图片生成过程，根据所获取的模块化练习数据量，分别生成 16×16，20×20 两种规格的图片。图片大小不同，所包含的成绩数量不同；图片越小，训练的时间越短。表 3 所示为采用两种不同图片格式的深度卷积神经网络大学英语四级成绩早期预警模型训练结果。从表 3 中可知，当图片大小为 20×20 时，模型的预测准确度更高。四级考试成绩预测无实时性问题，可忽略模型的训练时间。仅以预测准确度为指标，故本文所建模型选用 20×20 的输入图片规格。

表 2　不同规格图片对定位结果的影响

输入图片大小	预测准确度（%）	模型训练时间（s）
16×16	87.23	167
20×20	98.37	201

（三）确定最佳干预时间

为验证本文所建立的基于深度卷积神经网络的大学英语四级考试成绩早期预警模型的可用性、有效性及预测准确性，引入文献[10]和文献[12]所建立的模型，以预测准确率及召回率两个指标做对比分析。召回率指识别出的大学英语四级考试成绩未达标学生人数占学生总数的比率。设置该值超过 50%时的时间点为最佳干预时间。表 4 为第 1~20 周按双周进行成绩预测后得到的预测准确率及召回率，所有结果均取五折交叉验证平均值。结果表明，本文所建立模型的预测准确率在各个周次的表现均高于另两种模型。本文所建立模型的召回率在第 4 周时达到 50.48%，可确定为最佳干预时间。相对于其他两种模型给出的最佳干预时间（第 14 周和第 10 周），本文所建立模型得出的最佳干预时间提前量更大，为后期调整教学计划和方案预留了更多的时长，更有利于帮助学生在最大程度上达到预期成绩，全面提升英语听说读写译应用水平。

表 3　预警结果比较

（a）预测准确率对比

	第 2 周	第 4 周	第 6 周	第 8 周	第 10 周	第 12 周	第 14 周	第 16 周	第 18 周	第 20 周
本文采用方法	85.03	87.33	88.45	89.07	91.07	93.12	95.03	96.54	97.98	98.75
文献[10]方法	81.79	84.47	86.70	87.89	89.88	91.08	93.43	94.59	95.87	96.01
文献[12]方法	82.89	86.78	87.86	88.98	90.91	92.87	94.54	95.98	96.03	97.41

（b）预测召回率对比

	第 2 周	第 4 周	第 6 周	第 8 周	第 10 周	第 12 周	第 14 周	第 16 周	第 18 周	第 20 周
本文采用方法	47.73	50.48	54.07	56.72	58.66	62.70	67.98	74.81	78.43	82.09
文献[10]方法	39.78	40.66	43.01	45.09	47.18	49.89	51.34	56.77	60.02	62.17
文献[12]方法	40.09	44.87	47.70	49.87	52.65	57.92	61.01	63.27	66.70	72.61

（四）与其他算法的对比分析

在平台中另取 2022 年至 2023 年的四级模块专项训练相关数据，分别以本文的预测模型以及其他预测模型进行预测。各模型预测精度如图 5 所示。从图 5 中可知，本文所采用的方法在第 7 周时预测精度可达 98%左右，精度最高，时间最早。BP 模型预测精度在第 12 周左右达到 91%左右。RBF 的预测模型准确率最低。

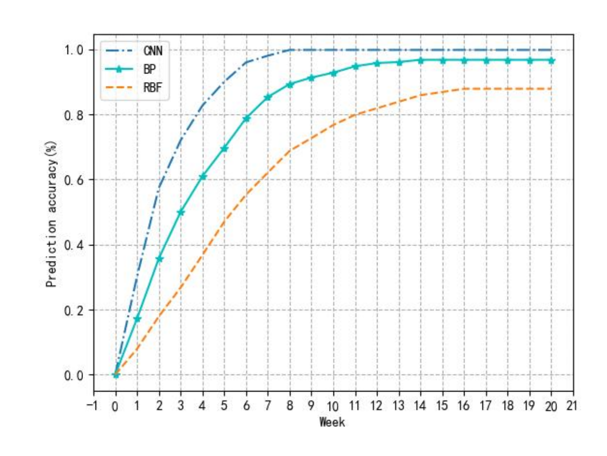


图 5　不同模型预测精度对比

五．结束语

本文以四级题型模块化训练过程中产生的相关信息为基础，研究大学英语四级考试成绩早期预警模型。首先寻找与预期成绩达标率相关性最高的因素，而后根据阅读、听力、写作与翻译四个学习模块建立相应的模块化学习灰度图片，构建基于深度卷积神经网络的大学英语四级早期预警模型，预测学生四级考试成绩达标率。本文同时讨论了模型预测正确率及召回率。以召回率大于 50%为阈值，寻找最佳的教学干预时间。为验证本文所建立模型的优越性，将本文模型与文中其他模型加以对比。结果表明，本文所建立模型的预测正确率最高，平均正确率可达 90%以上，且确定的最佳干预时间最早，能够在学习早期发现风险学生，增加了教学干预时长，提高了大学英语四级考试预期成绩达标率，提升了学生的英语应用能力。

[参考文献]

[1] 金艳,杨惠中.走中国特色的语言测试道路:大学英语四、六级考试三十年的启示[J].外语界, 2018(02): 29-39.

[2] E. Howard, M. Meehan & A. Parnell. Contrasing prediction methods for early warning systems at undergraduate level[J]. *The Internet and Higher Education*, 2018(37):66-75.

[3] A. Gökhan, N. Mohammad, R. Hasnine, B. Majumdar & O. Hiroaki. Developing an early-warning system for spotting at-risk students by using eBook interaction logs[J]. *Smart Learning Environments*, 2019(1): 4.

[4] 王华,刘萍.改进的关联规则算法在学生成绩预警中的应用[J].计算机工程与设计, 2015(03): 679-682+752.

[5] 宋楚平,李少芹,蔡彬彬.一种 RBF 神经网络改进算法在高校学习预警中的应用[J].计算机应用与软件, 2020(08): 39-44.

[6] 翁泉源. 基于 BP 神经网络和 Apriori 算法的教学成绩预测与分析研究[D].江西师范大学, 2018.

[7] P. M. Arsad, N. Buniyamin & J. A. Manan. A neural network students' performance prediction model (NNSPPM)[R]. In Proceedings of IEEE International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA). Kuala Lumpur, 2013:1-5.

[8] 郎波,樊一娜.利用学习向量化样本分类的在线学习成绩预测[J].计算机系统应用,2019(03): 215-222.

[9] 刘爱萍.基于数据挖掘技术的高校学生成绩预测模型构建[J].长春工程学院学报(自然科学版), 2020(02): 98-101.

[10] 姜绍萍.学生行为相关性分析及改进 GA-BP 学业预警算法[J].计算机系统应用,2021(04): 199-203.

[11] W. Hajra, H. Saeed-UL, R. A. Naif, H. Julie, A. Salem & N. Raheel. Predicting academic performance of students from VLE big data using deep learning models[J]. *Computers in Human Behavior*, 2020(104).

[12] 张明焱,杜旭,李浩.结合学生行为模式分析的成绩早期预警研究[J].计算机工程与应用, 2022(01): 1-8.

[13] 陈茂聪.溢洪道流量系数计算的相关性分析——基于人工神经网络模型[J].水利科学与寒区工程, 2019(04):

122-124.
［14］ 赵宏,郭万鹏.深度神经网络代价函数选择与性能评测研究[J].软件, 2018(01): 14-20.
［15］ 徐宝昌,吕爽,董秀娟等.基于 L2 正则化 LSTM 的非线性动态系统辨识[J].化工自动化及仪表, 2021(01):1-7.
［16］ 张有健,陈晨,王再见.深度学习算法的激活函数研究[J].无线电通信技术, 2021(01):1-7.

[英文版参考文献]（不同格式）

[1] Y. Jin, H.Z. Yang, “Developing language tests with Chinese characteristics: Implications from three decades of the College English Test,” *Foreign Language World, no.* 2, pp. 29-39, 2018.

[2] E. Howard, M. Meehan & A. Parnell, “Contrasting prediction methods for early warning systems at undergraduate level,” *The Internet and Higher Education, vol.* 37, pp. 66-75, 2018.

[3] A. Gökhan, N. Mohammad, R. Hasnine, B. Majumdar & O. Hiroaki, “Developing an early-warning system for spotting at-risk students by using eBook interaction logs,” *Smart Learning Environments, vol.* 6, no. 1, pp. 4, 2019.

[4] H. Wang, P. Liu, “Application of improved association rule algorithm in early warning of student performance,” *Computer Engineering and Design,* vol. 36, no.3, pp. 679-682+752, 2015.

[5] C. P. Song, S. Q. Li, & B. B. Cai, “Application of an Improved RBF Neural Network Algorithm in Learning Early Warning of Colleges,” *Computer Applications and Software* vol. 37, no. 8, pp. 39-44, 2020.

[6] Q. Y. Weng, “Research on Prediction and Analysis of Score Based on BP Neural Network and Apriori Algorithm,” M.S. thesis, SCIE, JXNU, Nanchang, CHN, 2018.

[7] P. M. Arsad, N. Buniyamin & J. A. Manan, “A neural network students' performance prediction model (NNSPPM),” in ICSIMA, KL, Malaysia, 2013, pp. 26-27.

[8] B. Lang, Y. N. Fan, “Method of Using Learning Vector Classification Samples to Predict Online Achievements,” *Computer Systems & Applications,* vol. 28, no. 3, pp. 215-222, 2019.

[9] A. P. Liu, “The Construction of College Students Performance Predictive Model Based on Data Mining Technology,” *Journal of Changchun Institute of Technology (Natural Sciences Edition),* vol. 21, no. 2, pp. 98-101, 2020.

[10]S. P. Jiang, “Correlation Analysis of Student Behavior and Improvement of GA-BP Academic Early Warning Algorithm,” *Computer Systems & Applications, vol.*30, no. 04, pp. 199-203, 2021.

[11]W. Hajra, H. Saeed-UL, R. A. Naif, H. Julie, A. Salem & N. Raheel. “Predicting academic performance of students from VLE big data using deep learning models,” *Computers in Human Behavior* vol.104, pp. 106189, 2020.

[12]M. Y. Zhang, X. Du & H. Li, “Research on Early Warning for Learning Performance Combined with Students’ Behavior Patterns Analysis,” *Computer Engineering and Applications,* vol. 58, no. 1, pp. 99-105, 2022.

[13]M. C. Chen, “Correlation analysis of spillway flow coefficient calculation-based on artificial neural network（ANN） model,” *Hydro Science and Cold Zone Engineering,* vol. 2, no. 4, pp. 122-124, 2019.

[14]H. Zhao, W. P. Guo, “Selection and Evaluation of Cost Function in Deep Neural Network,” *Software,* vol. 39, no. 1, pp. 14-20, 2018.

[15]B. C. Xu, S. Liu, X. J. Dong & J. Wang, “Identification of Nonlinear Dynamic System Based on L2 Regularized LSTM,” *Control and Instruments in Chemical Industry,* vol. 48, no. 1, pp. 1-7, 2021.

[16]Y. J. Zhang, C. Chen & Z. J. Wang, “Research on Activation Function of Deep Learning Algorithm,” *Radio Communications Technology, vol.* 47, no. 1, pp. 115-120, 2021.

An Early Warning Model of CET-4 Scores Based on Deep Convolution Neural Network

WANG Bao, LUO Miao

(School of Foreign Languages, Lanzhou Jiaotong University, Lanzhou Gansu 730070

Institute of Railway Technology, Lanzhou Jiaotong University, Lanzhou Gansu 730099)

Abstract: The early warning models of CET-4 scores are easily disturbed by the differences in students' daily behavior patterns, affecting prediction accuracy. A gray image database of students' modular learning is established using the CET-4 modular learning scores on a platform, and deep learning is integrated with early warning to form an early warning model of CET-4 scores based on deep convolution neural networks. An early prediction was made on whether students can achieve the expected results in CET-4. The results show that the prediction model based on the deep convolution neural networks has higher accuracy than the existing prediction models and can get an earlier optimal intervention time. It benefits teachers' intervention with relevant students and can help improve their CET4 scores and English language competency.

Key words: National College English Test Band 4, Early warning, Deep convolution neural network, Prediction accuracy, Optimal intervention time